

SUPERVISIÓN INTELIGENTE DE UN PROCESO COMPLEJO BASADA EN UN MODELO NEURONAL. UN CASO REAL DE APLICACIÓN.

Rodolfo E. Haber¹, J.R. Alique¹, A. Alique¹, A. Jiménez²

¹*Instituto de Automática Industrial (CSIC).
Km. 22,800 N-III, La Poveda. 28500. Madrid.
ESPAÑA
rhaber@iai.csic.es*

²*Escuela Técnica Superior de Ingenieros Industriales.
Universidad Politécnica de Madrid.
C/ José Gutiérrez Abascal, nº 2, Madrid 28006.
ESPAÑA.*

Resumen: An intelligent supervisory system inspired on a Neural Network Output Error model is presented herein. The application for predicting tool wear in a milling process is selected as a case study. The supervision block consists of a neural model, the weighted sum of squared residuals method and the tool condition index for a decision-making. This work shows the combined use of residual vector norm and the norm of the residual vector derivative to compute adaptive thresholds. The study analyses the influence of infinity and Euclidean norm on the results. Experimental tests are run in a professional machining centre under different cutting conditions using real-time data and new, half-worn and worn tools. The results show this supervisory system's suitability. *Copyright © 2006 CEA-IFAC*

Palabras Clave: process supervision, neural networks, milling process, multilayer perceptron, adaptive thresholds.

1. INTRODUCCIÓN

La supervisión inteligente está recibiendo cada vez más atención en los últimos años, debido en gran parte a que involucra el uso de modelos inteligentes que pueden mejorar la representación de las relaciones entre las entradas y las salidas de un sistema dinámico, incluyendo un reconocimiento implícito del comportamiento no lineal de algunos procesos (Haber *et al.*, 2002).

Los nuevos requisitos para la supervisión de los procesos de mecanizado han fomentado el estudio en los patrones de la fuerza de corte debido a su importancia para la evaluación del desgaste, de la rotura de las herramientas de corte, de la vibración en la máquina-herramienta y sus efectos en la calidad de la pieza mecanizada. Los modelos que involucran la fuerza de corte como variable de salida han sido estudiados tanto analítica como empíricamente con dos objetivos bien definidos. El primero, es

desarrollar sistemas inteligentes en tiempo real para la supervisión, objetivo de esta investigación (Du *et al.*, 1992). El segundo, es el diseño de controladores robustos y adaptativos para optimizar el proceso de mecanizado (Hekman&Liang, 1999), fuera de los objetivos del presente trabajo.

De todas las técnicas disponibles incluidos los sistemas borrosos y neuroborrosos (Haber-Guerra *et al.* 2006, Haber *et al.* 2005), los algoritmos basados en las redes neuronales artificiales (RNA) están entre los más convenientes para el análisis de información sensorial y la obtención de datos acerca del estado del proceso y de la herramienta (Alique *et al.*, 2000). Algunos resultados muestran que las redes neuronales artificiales pueden generar modelos más exactos que métodos clásicos tales como los métodos de regresión (Das *et al.*, 1996, Purushothaman, 1994).

A pesar de sus cualidades, las RNA no han sido tan bien acogidas por parte del sector tecnológico e industrial como las técnicas borrosas. A su excelente

capacidad de interpolación, se unen ciertas dificultades relacionadas con la poca precisión y exactitud en la extrapolación, lo que conduce a un reentrenamiento forzoso. De ahí que sea necesario un aprendizaje efectivo, que sólo es posible excitando el proceso suficientemente en la identificación y explorando un amplio rango de posibles condiciones de trabajo (Dimla *et al.*, 1997).

Este trabajo expone los primeros resultados de un sistema supervisor inteligente para la predicción del desgaste de la herramienta de corte, basado en un modelo neuronal. Con el fin de manejar las características no lineales del proceso, se propone una configuración de modelo neuronal del error de salida capaz de estimar en tiempo real la fuerza de corte en condiciones reales de mecanizado. El modelo sugerido describe la respuesta dinámica de salida del proceso (fuerza de corte resultante) ante cambios en las entradas (velocidad de avance y profundidad de corte). Un algoritmo de toma de decisión que usa los residuos (diferencia entre la fuerza de corte medida y la estimada por el modelo) se utiliza para detectar el desgaste de la herramienta.

2. MODELADO BASADO EN REDES NEURONALES ARTIFICIALES

Uno de los paradigmas de RNA más utilizado debido a su conveniencia para el modelado y control de procesos, es el llamado *Perceptrón Multicapa* (MLP). La clase de MLP considerada en este trabajo consiste en una capa oculta con función de activación tangente hiperbólica H . En la salida se utiliza una función de activación lineal L . Tal configuración es ventajosa con vistas a la implementación de la RNA en tiempo real.

$$\hat{y}_i(\mathbf{w}, \mathbf{W}) = L_i \left[\sum_{j=1}^Q W_{ij} H_j \left(\sum_{k=1}^M w_{jk} u_k + w_{j0} \right) + W_{i0} \right] \quad (1)$$

donde Q es el número de neuronas de salida, M es el número de neuronas en la capa oculta, \mathbf{U} es la entrada y \hat{y}_i es la salida de la red. Los pesos están definidos por las matrices \mathbf{w} (i.e., matriz de pesos que relaciona la entrada con la capa oculta) y \mathbf{W} (i.e., matriz de pesos que relaciona la capa oculta con la capa de salida). Ambas matrices son incluidas en la matriz de parámetros $\boldsymbol{\theta}$.

La solución al problema de la identificación puede ser visto como el mapeo desde un conjunto de datos $\mathbf{z}^N = [\mathbf{u} \ \mathbf{y}]^T$ (conjunto de entrenamiento) a un conjunto de posibles pesos ($\hat{\boldsymbol{\theta}}$), de manera que la red puede producir una predicción $\hat{y}(\mathbf{w}, \mathbf{W})$ tan cercana como sea posible a la salida real $y(t)$

$$\mathbf{z}^N \rightarrow \hat{\boldsymbol{\theta}} \quad (2)$$

Utilizando un método de identificación para la predicción de error,

$$E(\boldsymbol{\theta}, \mathbf{z}^N) = \frac{1}{2N} \sum_{t=1}^N (y(t) - \hat{y}(t|\boldsymbol{\theta}))^T (y(t) - \hat{y}(t|\boldsymbol{\theta})) \quad (3)$$

Los pesos son calculados como

$$\hat{\boldsymbol{\theta}} = \arg \min (E(\boldsymbol{\theta}, \mathbf{z}^N)) \quad (4)$$

Seleccionando como algoritmo de entrenamiento una versión del método de Levenberg-Marquardt. Después de esta breve explicación, la atención de este trabajo se centra en la obtención de un modelo dinámico no lineal a partir del entrenamiento con el método de Levenberg-Marquardt de una red neuronal de una sola capa oculta.

3. SISTEMA DE SUPERVISIÓN BASADO EN MODELO

La supervisión basada en modelo tiene muchas ventajas sobre el resto de los métodos (Issermann, 1989). Las técnicas de supervisión y diagnosis basadas en modelos establecen un umbral ε que determina los límites de los residuos, que se corresponden con condiciones normales de operación. El valor del umbral es determinante ya que un valor excesivamente bajo generaría demasiadas falsas alarmas y umbrales altos aumentarían la probabilidad de no detectar fallos existentes (Pnd). Fijar el valor crítico del residuo, por encima del cual se considere que existe un fallo, se convierte en una labor ardua. Este umbral se fija a partir de diferentes criterios estadísticos (varianza, desviación estándar, media), determinísticos (basado en medidas de distancia en espacios vectoriales) ó utilizando métodos basados en técnicas de inteligencia artificial (Haber *et al.*, 2005).

La evaluación de los residuos y la toma de decisión acerca de la condición o estado del proceso son dos etapas estrechamente vinculadas y esenciales para el funcionamiento adecuado del sistema supervisor. Dos sencillas estrategias son el método de la suma ponderada del cuadrado de los residuos (WSSR) y el método de la razón de verosimilitud generalizado (GLR) (Tzafestas&Watanabe, 1990, Willsky, 1976). A continuación se ofrece una breve explicación del método WSSR.

El método WSSR está basado en la secuencia de residuos ($e_M(t)$):

$$e_M(t) = y(t) - \hat{y}(t) \quad (5)$$

donde $y(t)$ es la salida real del proceso, $\hat{y}(t)$ es la salida estimada, y t es el tiempo discreto.

En condiciones ideales de funcionamiento, el proceso es considerado idealmente con ruido blanco y media cero con una matriz de covarianza $V_R(t)$ (Duda *et al.*, 2001). La desviación de una cierta variable η es usada para detectar fallos en base a un umbral (ε), calculado empíricamente, y utilizando una longitud de ventana de tiempo $[t-N_T-1: t]$. Un enfoque simple para establecer los niveles de umbrales es observar los residuos en los casos libre de fallos, y fijar el nivel adecuado para obtener la activación en los casos reales.

$$\eta = \sum_{t=N_T+1}^t e_M^T(t) \cdot V_R(t) \cdot e_M(t) \begin{cases} > \varepsilon \rightarrow \text{fallo} \\ \leq \varepsilon \rightarrow \text{no fallo} \end{cases} \quad (6)$$

En la actualidad, los trabajos en el tema del mejoramiento de la robustez del sistema de detección de fallos están dirigidos hacia la etapa de toma de decisiones. La mayor parte de estas técnicas se basan en la utilización de un umbral adaptativo en el modulo de toma de decisión. Se pueden utilizar diferentes estrategias adaptativas a partir de criterios heurísticos o utilizando funciones matemáticas exactas.

Son conocidas las relaciones directas entre la ocurrencia de fallos y las normas infinita y Euclidea de los vectores de residuos y su derivada. Así, el valor del umbral se puede actualizar dinámicamente en función del elemento de mayor magnitud en el vector de residuos $\varepsilon(t) \propto |\mathbf{e}_M|_\infty$ ó de su derivada $\varepsilon(t) \propto |\dot{\mathbf{e}}_M|_\infty$. En este trabajo se proponen dos criterios que combinan la influencia el vector de residuos y su derivada para el cómputo del umbral adaptativo. De este modo se aprovecha la información del vector de residuos y su derivada, no sólo para evaluar el grado de emparejamiento proceso-modelo, sino también para utilizar la tendencia en el vector de residuos en la detección del estado del proceso.

$$\varepsilon(t) = \frac{1}{|\mathbf{e}_M|_2 + |\dot{\mathbf{e}}_M|_2} \quad (7)$$

$$\varepsilon(t) = \frac{1}{|\mathbf{e}_M|_\infty + |\dot{\mathbf{e}}_M|_\infty} \quad (8)$$

donde $|\cdot|_\infty$ y $|\cdot|_2$ son la norma infinita y la norma Euclidea respectivamente; \mathbf{e}_M y $\dot{\mathbf{e}}_M$ son el vector de residuos y su derivada en la ventana $[t-N_T-1, t]$.

3.1 Detección de fallos y criterios de evaluación

Un aspecto importante en la última etapa de la detección de un fallo es el criterio o métrica de evaluación. En los módulos de detección se suele trabajar con dos categorías: situación de fallo y funcionamiento en condiciones normales. Cuando no se trabaja con estimaciones de probabilidades de pertenencia a una clase (fallo / no fallo) no resulta sencillo fijar un criterio o varios criterios relacionados con el estado del proceso.

No obstante, a partir de dos variables: hipótesis y clasificación realizada (fallo/ no fallo) es posible estimar las probabilidades *a posteriori* de fallo y no-fallo, lo cual puede ser muy útil en la toma de decisión acerca del estado del proceso. De este modo, contabilizando el número de casos en los que existe un fallo en el sistema y este es detectado *ca*, aquellos casos en los que no se detecta un fallo existente *cb*, y aquellas situaciones en las que es detectado un fallo y este no existe (falsas alarmas) *cc*, es posible calcular dos medidas muy útiles: la probabilidad de falsa

alarma *Pfa* y la probabilidad de no detección de fallo *Pnd*.

$$Pfa = \frac{cc}{cc + ca} \quad (9)$$

$$Pnd = \frac{cb}{ca + cb} \quad (10)$$

donde *Pfa*, es la proporción de casos en los que habiendo considerado que se corresponden a un fallo este no existe, y *Pnd*, es la proporción de casos en los que existiendo un fallo o avería en el proceso, no han sido detectados.

La validez de estos criterios estadísticos guarda mucha relación con el número real de casos analizados. En muchas ocasiones resulta más cómodo un criterio unificado que nos permita conocer el estado del proceso. El índice de condición del proceso (*PCI*), varía en un rango de 0% (situación normal) a un 100% (fallo en el proceso). El *PCI* se calcula descomponiendo la operación en varias ventanas de tiempo $[t-N_T-1, t]$ y cuantificando el número de ocasiones en las que se supera un umbral en cada ventana de tiempo analizada, así se define como

$$PCI = \frac{\sum_{k=1}^{NW} C_k}{NW} \cdot 100 \quad [\%] \quad (11)$$

$$C_k = \begin{cases} 1 & \forall \alpha = \eta - \varepsilon > 0 \\ 0 & \text{de otro modo} \end{cases}$$

donde $NW = N/N_T$ es el número total de ventanas en un proceso y C_k es un entero ($C_k \in [0, NW]$).

4. EL PROCESO DE FRESADO

El proceso de fresado ha sido escogido como caso de estudio entre todas las operaciones involucradas en el mecanizado. Esta elección obedece a un criterio pesimista, ya que el fresado es una de las operaciones de mecanizado más complejas debido a las características no lineales intrínsecas al proceso y al pobre rendimiento relativo de los sistemas de supervisión, en comparación con los procesos de torneado y rectificado (Sick, 1998). Por ejemplo, algunos estudios revelan que los sistemas de supervisión han sido aplicados (la mayoría a procesos de torneado y taladrado) para detectar rotura de la herramienta, desgaste de la herramienta y colisión con un 50%, 28% y 22% de éxito, respectivamente (Byrne, 1998).

Dentro de la enorme gama de variables y parámetros involucrados en la maquina herramienta y en el proceso de mecanizado deben ser seleccionados los factores más relevantes para las tareas de supervisión. Después de un estudio preliminar, los siguientes fueron escogidos: posición espacial de la herramienta de corte, considerando los ejes cartesianos. (x_p , y_p , z_p) [mm], velocidad de rotación (s) [rpm], velocidad de avance (f) [mm/min], potencia de corte usada en el

arranque de la viruta (P_c) [kW], fuerza de corte durante el arranque de la viruta (F) [N], profundidad radial de corte (a) [mm], diámetro de la herramienta de corte (d) [mm]. Existen otras propiedades y fenómenos físicos que influyen en el proceso, en ocasiones de forma aleatoria. Por ejemplo, existen diferencias en el estado (grado de desgaste y rotura) y la geometría de la herramienta, variación en la dureza de la pieza (composición del material), estructura de la máquina (rigidez), vibración no lineal, y también diversas restricciones en las medidas de los sensores (costo, conexión, sensibilidad, linealidad, precisión, fiabilidad).

Sobre la base del enfoque sistémico anteriormente mencionado y dirigido a una supervisión inteligente, el proceso de fresado puede ser formalmente descrito por una relación discreta no lineal.

$$\hat{F}(t) = G(\mathbf{F}, \mathbf{f}, \mathbf{a}) \quad (12)$$

donde G es una función desconocida a identificar y \mathbf{f}, \mathbf{a} y \mathbf{F} son las entradas y salidas respectivamente definidas como

$$\mathbf{F} = [F(t-1) \ \dots \ F(t-n)], \mathbf{f} = [f(t-1), \ \dots \ , f(t-m)],$$

$$\mathbf{a} = [a(t-1) \ \dots \ a(t-m)], t \text{ es el instante de tiempo y } n, m \in \mathbb{Z}.$$

Si el modelo es obtenido por medio de un esquema de identificación paralela, el resultado estimado de la salida podría ser

$$\hat{F}(t) = g(\hat{\mathbf{F}}, \mathbf{f}, \mathbf{a}) \quad (13)$$

donde g representa la función entrada-salida desarrollada por la RNA, $\hat{\mathbf{F}} = [\hat{F}(t-1), \ \dots \ , \hat{F}(t-n)]$ y $\hat{F}(t)$ es la estimación del modelo.

4.1 Proceso de supervisión en el mecanizado. Detección del desgaste de la herramienta de corte.

Usualmente durante el mecanizado los operadores centran sus tareas en el chequeo de los valores límites, verificación de las secuencias de la operación, vigilancia de la máquina herramienta y dispositivos periféricos, la geometría de la viruta, las vibraciones y las condiciones de la herramienta de corte (desgaste o rotura). Asimismo, también llevan a cabo acciones correctivas para ajustar las condiciones de mecanizado.

El desgaste de la herramienta se produce debido a una combinación de varios fenómenos, aunque es un evento inherente al proceso de corte. El desgaste de la herramienta puede ocurrir gradualmente o de forma drástica. El desgaste gradual se puede producir por adhesión, abrasión o difusión, y puede aparecer en dos formas: desgaste en la superficie de la herramienta o desgaste en su flanco. En la superficie de la herramienta, el contacto con la viruta puede producir cráteres. El desgaste del flanco, por otra parte, es comúnmente debido a la fricción entre la herramienta y el material de la pieza de trabajo.

Dos criterios ampliamente utilizados para detectar el estado de la herramienta de corte son las fallas catastróficas y el cambio en la geometría de la herramienta. Otros criterios utilizados son el acabado superficial de las piezas, la desviación en la fuerza de corte, el incremento en el consumo eléctrico, el recalentamiento y la aparición de vibraciones.

5. PLATAFORMA EXPERIMENTAL

Los ensayos fueron realizados en una máquina fresadora de 4 ejes equipada con CNC y un computador personal. Se desarrolló una arquitectura hecha a la medida para la supervisión del proceso de fresado (ver Figura 1).

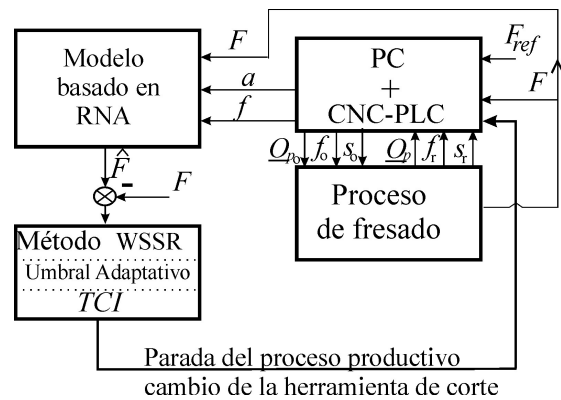


Fig. 1 Esquema para la supervisión del proceso de fresado.

El ordenador personal ha sido utilizado para realizar dos importantes tareas. Primero, evalúa los valores medidos de la fuerza de corte y genera los valores \hat{f} . En segundo lugar, y principal objetivo de este trabajo, se implementó un sistema de supervisión constituido por un modelo del proceso (13) y el algoritmo WSSR (ver Sección 3). El objetivo del modelo es estimar en tiempo real, anticipadamente, la fuerza de corte resultante \hat{F} . El proceso de detección del fallo, que en este caso se trata del desgaste de la herramienta, se realiza a partir del algoritmo WSSR, y de la toma de decisión basada en los umbrales adaptativos. Si la herramienta está suficientemente gastada, la decisión final es detener el proceso y sustituir la herramienta.

Los datos de entrada para la identificación del modelo fueron obtenidos de la señal de avance f , la profundidad de corte a y la señal de la corriente del motor del husillo recogidos a una frecuencia de muestreo de 10 kHz. Una biblioteca de calibración proporciona valores reales de F a partir de la señal de corriente consumida por el husillo (Haber *et al.*, 2002).

En la fase de entrenamiento de la RNA sólo se utilizaron herramientas nuevas. Dos piezas diferentes se escogieron para el entrenamiento de la RNA (ver Figura 2A) para la verificación del modelo en tiempo real (Figura 2B). Para los experimentos, la posición espacial de la herramienta de corte fue siempre mantenida en una posición vertical constante. La

operación de de desbaste se realizó en una sola dirección (ver Figura 2C).

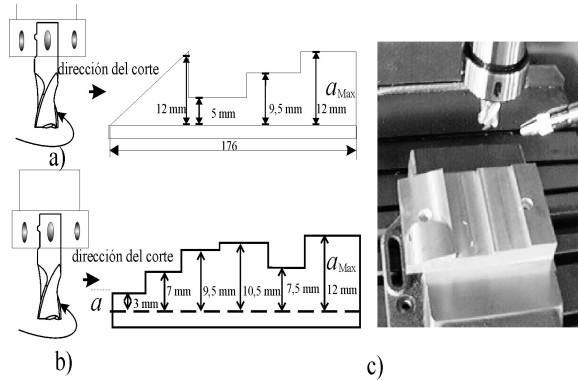


Fig. 2. Pieza de trabajo para, a) entrenamiento, b) validación, c) el fresado

5.1 Modelo Neuronal del Proceso de Fresado. Metodología de Evaluación.

Los datos fueron sometidos a un procesamiento preliminar antes del entrenamiento (Bendat, 2000). El algoritmo de entrenamiento fue desarrollado utilizando MATLAB. La topología fue inicialmente escogida como sigue: dos entradas f y a , una salida \hat{F} , una función de activación lineal en la salida, y una capa interna utilizando la función tangente hiperbólica para la activación. El tipo de modelo fue seleccionado basado en el conocimiento *a priori* del proceso de fresado y de los tipos de modelos considerados en trabajos anteriores por los autores. De todos los modelos analizados, se escogió una RNA con seis neuronas en la entrada, doce neuronas en la capa oculta y una neurona en la capa de salida. Después de modificar (13) para un modelo OE de segundo orden, se obtuvo:

$$\hat{F}(t) = g(\hat{F}(t-1), \hat{F}(t-2), f(t-1), f(t-2), a(t-1), a(t-2)) \quad (14)$$

Los valores iniciales de los pesos fueron seleccionados de forma aleatoria. Las condiciones iniciales de corte fueron $f_0=100$ mm/min, $s_0=1000$ rpm y $a_0=6$ mm. Al final de la etapa de entrenamiento, se ejecutó un algoritmo de poda para optimizar el tamaño de la red y eliminar pesos superfluos (Hassibi *et al.*, 1994).

Para validar el modelo, se realizaron varios análisis (valor medio cuadrático, auto-correlación y estudios de datos transitorios). Las pruebas de verificación se realizaron con otro perfil (mostrado en Figura 3b) en una operación de corte similar con herramientas nuevas, semidesgastadas y desgastadas. Los resultados fueron muy similares durante las pruebas de validación. De estos resultados se puede inferir que las características del modelo y su capacidad de generalización son buenas ya que refleja de forma adecuada las propiedades dinámicas específicas del proceso.

5.2 Estimación del desgaste de la herramienta de corte.

La diferencia entre la fuerza de corte real y la estimada por el modelo neuronal se utilizó para generar los residuos (5). Por consiguiente, la desviación de la fuerza de corte es el criterio primario para inferir las condiciones de la herramienta.

El PCI (11) ha sido particularizado como índice de condición de la herramienta (TCI), el cual varía en un rango de 0% (herramienta completamente nueva) a 100% (herramienta desgastada) y se utilizó para detectar el estado de la herramienta. Para fabricar una pieza sencilla se realizan varias operaciones de mecanizado, incluyendo desbaste, semiacabado, acabado y pulido por lo que cada operación está compuesta por varias ventanas de tiempo $[t-N_T-1, t]$ dependiendo del tiempo total del mecanizado.

La evaluación de los residuos y la toma de decisión se llevó a cabo usando el método WSSR descrito en la Sección 3. Se examinaron diferentes umbrales fijos ε y diferentes tamaños de ventanas de tiempo N_T . Debido a la incertidumbre y al ruido inherente al proceso, era de esperar que los residuos generados en los casos libres de fallos (i.e., herramientas nuevas) no fueran cero.

En la Figura 3 se muestra el comportamiento del TCI con respecto al umbral ε y al tamaño de la ventana N_T para una herramienta nueva, semidesgastada y gastada. De este estudio se obtuvo que la dupla $(\varepsilon, N_T) = (0.1, 20)$ permite obtener valores adecuados del TCI , así como un comportamiento aceptable de la probabilidad de falsa alarma $Pfa=0.06$ y de la probabilidad de no detección de fallo $Pnd=0.16$. De este modo, se obtuvo $\varepsilon=0.1$ y $N_T=20$. De esta manera se obtuvo un umbral superior a cero con vistas a rechazar información que pudiera conducir a falsas alarmas.

Con vistas a mejorar la robustez del algoritmo se utilizó un umbral adaptativo. Para el cálculo de los umbrales se utilizó un nuevo método en el cual el valor del umbral es continuamente calculado a partir de la norma infinita (ó la norma Euclídea) del vector \mathbf{e}_M y su derivada $\dot{\mathbf{e}}_M$.

Para ello se utilizaron las ecuaciones (7) y (8) en cada ventana de tiempo $[t-N_T-1, t]$. La evaluación del sistema se realizó usando como criterios básicos la habilidad para reducir las falsas alarmas y detectar el desgaste de la herramienta. A partir del modelo neuronal y el método WSSR, se realiza un chequeo continuo para averiguar si el TCI es mayor que un valor crítico (ε para umbrales fijos ó $\varepsilon(t)$ para umbrales adaptativos), en tales casos se asume que la herramienta esta desgastada. La comparación se efectuó en diferentes condiciones de corte usando datos de tiempo real de herramientas nuevas, semidesgastadas y gastadas.






Fig. 3. Comportamiento de la Pfa y el Pnd versus N_T y ε

En la Figura 4 se ilustra la respuesta del modelo en tiempo real ante cuatro situaciones que frecuentemente conducen a la aparición de falsas alarmas a pesar de estar nueva la herramienta. El primer caso analizado (figura 4a) se corresponde a un cambio en el material mecanizado (aluminio 7075), el segundo a un cambio en la probeta mecanizada (Figura 4b), en el tercer caso las oscilaciones en la fuerza de corte son debido a condiciones de corte inapropiadas (Figura 4c) y finalmente se consideró la situación en la cual se produce un cambio brusco en la fuerza de corte por una perturbación. La tabla I resume el comportamiento de todos los criterios analizados. No se aprecian diferencias significativas en el cambio de material mecanizado (caso 1), sin embargo las situaciones 2, 3 y 4 anteriormente descritas producen peores resultados con el umbral fijo ($TCI=15.2\%$, 31.6% y 33.2% , respectivamente). El umbral adaptativo basado en (8) produce los mejores resultados.



a)



b)





Fig.4 Comportamiento del modelo neuronal en la predicción de la fuerza de corte a) caso 1, b) caso 2, c) caso 3, d) caso 4.

Herramienta nueva	$\varepsilon(t)$ (7)		$\varepsilon(t)$ (8)		$\varepsilon=0.1$	
	Pfa	TCI	Pfa	TCI	Pfa	TCI
Caso 1. cambio en el tipo de material mecanizado	0.08	12.1	0.08	12.2	0.11	15.2
Caso 2. cambio en la probeta mecanizada	0.06	6.9	0.06	6.9	0.06	6.9
Caso 3. condiciones de corte inapropiadas	0.19	32.2	0.14	23.1	0.19	33.2
Caso 4. cambio brusco por una perturbación	0.40	25.9	0.37	23.2	0.45	31.6

Tabla I TCI y Pfa para las situaciones 1, 2, 3 y 4.

CONCLUSIONES

El sistema de supervisión inteligente propuesto intenta solventar con éxito dos cuestiones neurálgicas del sistema de supervisión del proceso de fresado, todavía no resueltos en su totalidad: la carencia de capacidad efectiva de diagnóstico del estado de la herramienta de corte y la inconsistencia de los sistemas actuales con las variaciones del proceso.

La metodología para fijar los umbrales usada en este trabajo difiere de las estrategias actuales ya que el umbral es generado en tiempo real a partir de la norma del vector de residuos y su derivada (infinita o Euclidea). El estudio del comportamiento de los umbrales adaptativos ante diferentes situaciones (condiciones de corte inapropiadas, cambio brusco en los parámetros de corte, cambio de la pieza) demuestra que la norma infinita (8) ofrece mejores resultados.

El tamaño medio de la ventana ($N_T=20$) proporciona a la estrategia una capacidad de memorizar, y por lo tanto efectos tales como la adhesión de la viruta y su acumulación no causan falsas alarmas, ya que el umbral ha memorizado dicho efecto. Además, como el valor del umbral se actualiza de forma continua, la estrategia puede funcionar con operaciones de corte de duración variable.

REFERENCIAS

- Alique, A., Haber, R. E., Haber, R. H., Ros, S., & Gonzalez, C. (2000). Neural network-based model for the prediction of cutting force in milling process. A progress study on a real case. Paper presented at the *IEEE International Symposium on Intelligent Control - Proceedings*.
- Bendat J.S., Piersol A.G. (2000), *Random Data, Analysis and Measurement Procedures*. 3rd. Edition, Wiley & Son.
- Byrne G., Dornfeld D., Inasaki I. (1995), Tool condition monitoring (TCM)- the status of research and industrial application, *Annals of the CIRP* **44(2)**, pp. 541-567.
- Das S., Chattopadhyay A.B., Murthy A.S.R. (1996), Force parameters for on- line tool wear estimation - a neural network approach, *Neural Networks* **9(9)**, pp. 1639-1645.
- Dimla D.E., Lister P.M., Leighton N.J. (1997), Neural network solutions to the tool condition monitoring problem in metal cutting – a critical review of methods, *Int. J. of Machine Tools Manuf.* **37(9)**, pp. 1219-1241.
- Du R.X., Elbestawi M.A., Li S. (1992), Tool condition monitoring in turning using fuzzy sets theory, *Int. J. of Machine Tools Manuf.* **32(6)**, pp. 781-796.
- Duda R.O., Hart P.E., Stork D.G. (2001), *Pattern Classification*. 2nd edition, Wiley, New York.
- Haber, R. E., Haber, R., Alique, A., & Ros, S. (2002). Application of knowledge-based systems for supervision and control of machining processes. *Handbook of software engineering and knowledge engineering*, **2**, 673-710.
- Haber, R. E., Cantillo, K., & Jiménez, J. E. (2005). Networked sensing for high-speed machining processes based on CORBA. *Sensors and Actuators A: Physical*, **119(2)**, 418-426.
- Haber, R. E., Alique, J. R., Alique, A., & Haber, R. (2005). Controlling a complex electromechanical process on the basis of a neurofuzzy approach. *Future Generation Computer Systems*, **21(7)**, 1083-1095.
- Haber-Guerra, R., Liang, S. Y., Alique, J. R., & Haber-Haber, R. (2006). Fuzzy control of spindle torque in high-speed milling processes. *Journal of manufacturing science and engineering*, **128(4)**, 1014-1018.
- Hassibi B., Stork D.G., Wolf G., Watanabe T. (1994), Optimal brain surgeon: Extensions, streamlining and performance comparisons *Advances in Neural Information Processing Systems* **6**, 263-271.
- Hekman K.A., Liang S.Y., Feedrate optimization and depth of cut control for productivity and part parallelism in grinding, *Mechatronics* **9**, (1999), pp. 447-462.
- Isermann R. (1984), Process fault detection based modelling and estimation methods- A survey *Automatica* **20(4)**, pp. 387-404.
- Martin, A. G., Guerra, R. E. H. (2009). Internal model control based on a neurofuzzy system for network applications. A case study on the high-performance drilling process. *IEEE Transactions on Automation Science and Engineering*, **6(2)**, 367-372.
- Purushothaman S., Srinivasa Y.G. (1994), A back-propagation algorithm applied to tool wear monitoring, *Int. J. of Machine Tools Manuf.* **34(5)**, pp. 625-631.
- Sick B. (1998), On-Line Tool wear monitoring in turning using neural networks, *Neural Computing & Applications* **7(4)**, 356-366.
- Tzafestas S., Watanabe K. (1990), Modern approaches to system sensor fault detection and Diagnosis, *Journal A* **31(4)**, 42-57.
- Willsky A.S. (1976), A survey of design methods for failure detection in dynamic systems, *Automatica* **12**, 601-611.